

スキーマ貪欲な集団型探索アルゴリズムの構成

3P-5

相澤 彰子

(学術情報センター)

1はじめに

本稿では、確率的スキーマ貪欲法 (SSE, Stochastic Schemata Exploiter) と呼ぶ新しい集団型探索アルゴリズムを構成する。 SSE は GA と同様に、スキーマと呼ばれる超平面表現の処理により解空間を探索するが、GA と比較して局所的探索処理を重視している点が特徴である。

従来より GA に関しては、その適応的な大域的探索能力が長所として強調されてきた。これに対して SSE では、現実の最適化問題への適用では GA の大域的探索能力が必ずしも有効な形で反映されないという観点から、GA の大域的探索処理を、集団型探索の特徴を生かしつつ簡単化して、制御パラメタの数が少なく単純な探索法を実現している。

本稿では、まず SSE の構成法を概観し、次に SSE を GA 容易問題、GA 困難問題、さらにハイブリッド手法に適用して単純 GA と比較・評価を行う。

2 SSE：確率的スキーマ貪欲法

SSE では、まず手順(1)として、個体集団の優れたものの中から共通ビットを取り出し有用なスキーマを抽出する。次に手順(2)として、得られた有用なスキーマに基づき確率的な方法で新たな個体を生成する [1]。

手順(1)では、各個体の評価値に基づき個体部分集合を平均評価値のよいもの順に並べ、上位の部分集合から順に共有スキーマを取り出す。個体の部分集合をスキーマと対応づけている点が特徴である。手順(2)では、手順(1)で得られたスキーマの^{**}(任意)ビット部に0または1を割り当て、ランダムに個体を発生する。この操作は親の数を2から任意個に拡張した均一交叉となっている。さらに突然変異操作を用いて集団中に多様性を取り込む。突然変異率はアルゴリズムの制御パラメタとする。

手順(1)について、GA におけるスキーマの選択は原則として、各々の個体の評価値を用いて確率的に行われる。一方、SSE においてはスキーマの選択は確率的ではなく、優れた個体部分集合で共有される部分解として一意に決定される。このため GA と比較して、局所解に引き付けられる「貪欲的な」傾向が強くなると予想される。

手順(2)について、GA における個体の生成は、交

又により多くの有用なスキーマを効率よく集めることにより、ランダムな探索より高い性能を実現することが特徴であった。一方、SSE においてはスキーマのサンプルはランダムに行われ、組み合わせによる効果は考慮していない。このため GA が効率よく動作している場合には、大域的な探索は不利になる可能性がある。

3 動作比較のためのパラメタ設定とテスト問題

SSE の特徴を評価するため、簡単なテスト問題を用いて比較実験を行った。実験では、(1) 世代ごとに個体を入れ換える単純 GA (BGA, basic GA)、(2) GA において、操作子として突然変異のみを用いる確率的山登り法 (SHC, Stochastic Hill Climber)、および本稿で述べた(3) 確率的スキーマ貪欲法 (SSE) の3者について動作比較を行った。

設定したパラメタの値は、BGA、SHC および SSE について、個体集団の大きさ 100、突然変異率 0.001 である。また、最良解保存戦略を用いた。さらに、BGA について交叉率 0.6 とし、BGA と SHC については、スケーリングのウィンドウサイズを文献[2]にしたがい 7 に設定した。また、以下の結果中では、各世代 t における最良の個体の評価値を探索アルゴリズムの性能値としている。

テスト問題としては、評価値がストリング中の'1'の数で与えられる単純な問題を用いた。これは、DeJong のテスト問題等を 4.2 の手法により解析した結果、コード化技法により問題の性質が大きく変わることが観察されたため、コード化の影響が少ない問題として選んだものである。まず、ストリング長 L として、ストリング x の中に含まれる'1'の数を $\text{count}(x)$ で表す。典型的な GA 容易問題である'1'数え上げ問題では、 x に対する評価値は次式で与えられる。

$$f(x) = \text{count}(x). \quad (1)$$

一方 GA の困難問題として、 $a < b, 0 < c < L$ なる整数 a, b, c を考え、ストリング x に対する評価値が以下の式で定義される場合を考える。

$$f(x) = \begin{cases} \frac{a(c - \text{count}(x))}{(L - c)} & (\text{count}(x) < c) \\ \frac{b(\text{count}(x) - c)}{(L - c)} & (\text{count}(x) \geq c) \end{cases}. \quad (2)$$

ここで $c = (L - 1)$ のとき上式は完全困難であり、それ以外の場合は部分困難である。

4 動作比較例(1)：GA 容易問題への適用

まず、局所的な探索処理能力を比較するため、GAB, SHC, SSE を式(1)のテスト問題に適用した。この問題は GA 容易であり、GA などスキーマ処理に基づく探索法は容易に最適解に到達することが予想される。

実験では、各探索法が最適解に到達した最初の世代数を記録し、平均値を調べた。図1に、ストリング長 L を $(80, 160, \dots, 480)$ と変化させ、各々についてシミュレーションを 100 回繰り返した結果を示す。いずれの場合についても、SSE は、GAB や SHC と比較して、速い収束性を示していることがわかる。

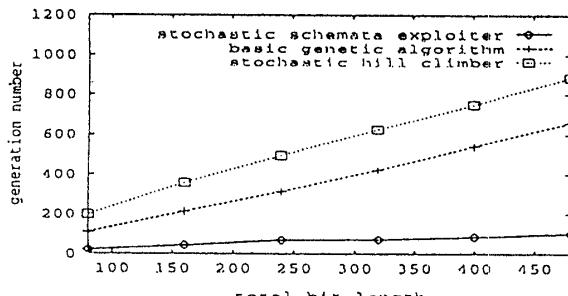


図1: GA 容易問題への適用による動作比較

5 動作比較例(2)：GA 困難問題への適用

次に、大域的な探索処理能力を比較するため、GAB, SHC, SSE を式(2)のテスト問題に適用した。この問題は GA 部分困難問題であり、その困難性はテスト問題のパラメタ c に依存すると予想される。

実験では、各探索法を最高 10,000 世代まで実行し、最終的に最適解に到達するかどうかを判定した。図2に、ストリング長を $L = 160$ とし、 $a = 59$, $c = 60$ に設定して c を変化させた場合の結果を示す。図中、横軸は c の値、縦軸は試行 50 回中の成功率である。BGA, SHC, SSE は、ほぼ等しいふるまいを示し、 $c \geq L/2 (= 80)$ に対して成功率 1.0, $c < L/2$ に対して成功率 0.0 である。これは、これらの探索法がすべて、だまし問題に対して頑強ではないことを示すと考えられる。

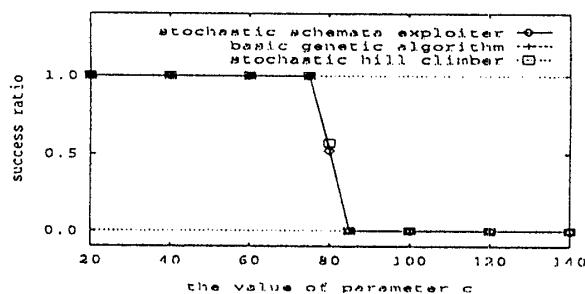


図2: GA 困難問題への適用による収束率の比較

6 動作比較例(3)：探索法の拡張

最後に、ハイブリッド化における BGA と SSE の適性を比較するため、両者に局所解を脱出するための簡単なルーチンを加えて性能を調べた。

拡張した探索法では、集団が局所最適解に陥ったことを判定して以下の手順を行う。まず、対象となる局

所解を集団から取り除き、異なるメモリ領域に保存する。次に、その局所解からのハミング距離がランダムに与えられる M 個の個体を生成して、新たな集団とする。これにより集団中に多様性が導入され、新しい領域の探索が始められる。ただし、この処理は集団が収束した場合にのみ起動されるため、通常の局所的探索動作には影響を与えない。

BGAにおいては、集団の中の $\alpha\%$ 以上の個体が等しい場合に、探索が収束したとみなす。ここでは $\alpha = 80$ としている。一方、SSEにおいては、順位づけされた M 個のスキーマの次数の総数が ML 、すなわち、どのスキーマも '*'を持たない場合に、探索が収束したと判断する。

図3に、このようにして拡張した BGA と SSE を式(2)のテスト問題に適用した結果を示す。シミュレーションの条件は、図2の場合と同じである。図中の横軸は c の値、縦軸は 50 回のシミュレーションにおける平均の終了世代数を示している。拡張した探索法では両者とも例外なく、10,000 世代以内に最適解を発見することができた。そして、拡張した SSE は拡張した BGA よりもよい性能を示していることがわかる。

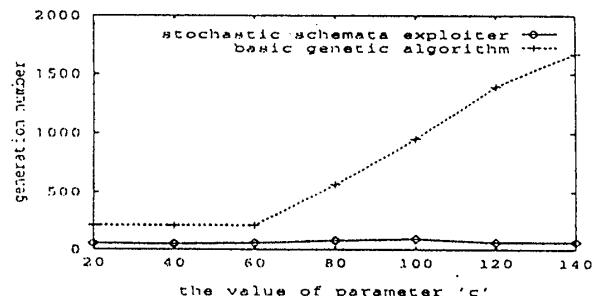


図3: GA 困難問題への適用による動作比較

7 おわりに

SSE は GA と比較して簡単化した大域的探索を行いうため、はやい収束特性を持ち、制御パラメタの数も少ないという利点がある。本稿では、簡単な GA 容易/困難問題を用いて評価を行い、SSE が単純 GA よりも局所的探索に優れ、かつ適用したテスト問題の範囲で、ほぼ同等の大域的探索の能力を持つことを示した。

また本稿では、SSE と単純 GA に対して局所解を脱出するための特別な手順を加え、拡張した 2 つの探索法の性能を比較した。その結果、拡張した SSE について、拡張した GA よりも優れた性能が得られ、ハイブリッド手法において SSE の持つ速い収束特性が有利となる可能性を示した。

今後の課題として、より複雑なだまし問題を用いた評価や、現実的なアプリケーションへの適用などがあげられる。

参考文献

- [1] 柏澤彰子: “スキーマ処理に基づく集団型探索アルゴリズム”, 情報処理学会人工知能研究会 (1994 年 3 月).
- [2] Grefenstette, J. J.: “Optimization of Control Parameters for Genetic Algorithms,” IEEE trans. on Sys. Man & Cyber., Vol. SMC-16, No. 1, pp.122-128 (1986).